

# DỰ ĐOÁN CÔNG SUẤT TỐI ƯU NGUỒN PHÁT CỦA HỆ THỐNG TRUYỀN GÓI TIN NGẮN QUA MẶT PHẢN XẠ THÔNG MINH BẰNG KỸ THUẬT HỌC SÂU

Nguyễn Thị Yến Linh\*, Võ Nguyễn Quốc Bảo\*, Phạm Ngọc Sơn\*

\*Học Viện Công Nghệ Bưu Chính Viễn Thông

\* Trường Đại học Sư Phạm Kỹ Thuật Thành Phố Hồ Chí Minh

**Tóm tắt-** Trong bài báo này, chúng tôi đề xuất mô hình mạng nơ ron sâu để dự đoán công suất tối ưu nguồn phát của hệ thống truyền tin gói ngắn qua mặt phản xạ thông minh phù hợp yêu cầu uRLLCs. Đầu tiên, chúng tôi dẫn ra biểu thức xấp xỉ tỉ lệ lỗi khối qua kênh truyền fading Rayleigh. Dựa trên biểu thức tỉ lệ lỗi khối, chúng tôi tạo tập dữ liệu cho quá trình huấn luyện mạng nơ ron sâu và tiến hành kiểm tra kết quả dự đoán với một tập kiểm thử bất kỳ. Cuối cùng, để đánh giá chất lượng dự đoán của mô hình mạng nơ ron, chúng tôi dựa vào phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE). Kết quả cho thấy rằng RMSE nhỏ (khoảng  $10^{-2}$ ) và giá trị này càng giảm khi tăng số lượng mẫu kiểm tra.

**Từ khóa-** kỹ thuật học sâu, mặt phản xạ thông minh, fading Rayleigh, tỉ lệ lỗi khối, truyền thông gói tin ngắn.

## I. GIỚI THIỆU

Trọng tâm của mạng truyền thông không dây thế hệ thứ năm (5G) và mạng không dây thế hệ tiếp theo (6G) là cung cấp dịch vụ đáng tin cậy cho các ứng dụng khác nhau với mục tiêu thiết kế sao cho thông lượng cao, giảm độ trễ đầu cuối và kết nối nhiều thiết bị [1, 2]. Do đó, giao tiếp cực kỳ tin cậy và độ trễ cực thấp (uRLLCs) được xem là yêu cầu chính cần đạt được của các hệ thống mạng không dây thế hệ mới nhằm hỗ trợ các ứng dụng mọi vật kết nối mạng (IoT) như tự động hóa công nghiệp, giao tiếp phương tiện kết nối mọi vật (V2X), thực tế ảo (VR) và thực tế tăng cường (AR) [3]. Dịch vụ uRLLCs yêu cầu nghiêm ngặt cả về độ tin cậy cực cao (99.9999%) và độ trễ phải cực thấp (1ms) [4]. Để đáp ứng yêu cầu cao về độ tin cậy và độ trễ thấp trong uRLLCs, phương thức giao tiếp qua gói tin ngắn được xem như là giải pháp tiềm năng và chỉ được hỗ trợ trong các hệ thống giao tiếp không dây thế hệ mới [5, 6]. Cụ thể, các nghiên cứu gần đây cho thấy sự cải thiện về độ tin cậy và giảm độ trễ của hệ thống giao tiếp qua gói tin ngắn trong mạng chuyên tiếp cộng tác [7-10]. Hơn nữa, gần đây các nhà nghiên cứu còn cho thấy khả năng cải tiến hiệu năng và giảm độ trễ khi nghiên cứu truyền gói tin ngắn kết hợp mặt phản xạ thông minh (IRS)

[11, 12]. So với mạng chuyên tiếp cộng tác AF và DF thì chuyên tiếp qua IRS cải thiện hiệu năng hệ thống [13], mở rộng vùng phủ (tức khoảng cách truyền và nhận tín hiệu từ nguồn đến đích dưới sự hỗ trợ của IRS lớn hơn so với khoảng cách truyền và nhận tín hiệu giữa nguồn và đích qua nút chuyên tiếp), và tiết kiệm công suất phát của nguồn hơn do IRS chỉ đơn thuần phản xạ thụ động tín hiệu mà không cần bổ sung công suất [14, 15]. Hiện nay, để đảm bảo chất lượng dịch vụ cao (QoS) và độ trễ nghiêm ngặt của uRLLC đáp ứng yêu cầu dịch vụ của các hệ thống mạng tương lai, học sâu (DL) được công nhận là một giải pháp khả thi để giải quyết nhiều đề thực tế, chẳng hạn như dự đoán hiệu suất mạng, kiểm soát tắc nghẽn, quản lý hàng đợi và phân bổ tài nguyên cho hệ thống IoE [8]. Đặc biệt, một mô hình của học sâu là mạng nơ ron sâu (DNN). Đây là một trong những mô hình DL tiềm năng được quan tâm để giảm thiểu độ phức tạp tính toán và để đáp ứng các yêu cầu thời gian thực của các hệ thống mạng trong tương lai [16].

### A. Các nghiên cứu liên quan

Gần đây, các nhà khoa học đã cho thấy sự cải thiện hiệu năng và giảm độ trễ của giao tiếp gói tin ngắn như trong các bài báo [7-10]. Trong [7], các tác giả chứng tỏ so với truyền gói tin dài thì truyền gói tin ngắn qua nút chuyên tiếp đạt độ tin cậy cao hơn khi xét ở trạng thái kênh truyền hoàn hảo và đạt hiệu năng vượt trội ở giao thức giải mã và chuyên tiếp (DF) như trong [8]. Tiếp tục, bài báo [9] cho thấy độ tin cậy cao của kỹ thuật lựa chọn nút chuyên tiếp bán phân (PRS) để truyền gói tin ngắn trong hệ thống chuyên tiếp DF. Ở bài báo [10] hệ thống đa anten được thiết kế ở nguồn thu và giao thức tỉ số kết hợp cực đại (MRC) được sử dụng nhằm đạt độ phân tập cao, cải thiện hiệu năng truyền gói tin ngắn của hệ thống chuyên tiếp DF. Bên cạnh đó, gần đây mặt phản xạ thông minh đã được chứng minh là một biện pháp hữu hiệu cải tiến hiệu năng hơn hẳn mạng chuyên tiếp. Cụ thể, bài báo [13] cho thấy hiệu năng và độ lợi phân tập của mạng chuyên tiếp qua mặt phản xạ thông minh cải thiện hơn chuyên tiếp qua nút chuyên tiếp DF. Đặc biệt, chuyên tiếp DF có độ lợi phân tập cao hơn chuyên tiếp AF trong truyền tin gói tin dài. Đối với truyền thông tin gói ngắn có sự hỗ trợ của mặt phản xạ thông minh cũng đạt được sự cải tiến vượt bậc. Ở bài báo [11], các tác giả đã chứng minh được truyền tin gói ngắn qua mặt phản xạ thông minh đạt được độ lợi phân tập cao hơn hệ thống chuyên tiếp DF với cùng công suất

Tác giả liên hệ: Nguyễn Thị Yến Linh,

Email: [linhty.ncs@hcmute.edu.vn](mailto:linhty.ncs@hcmute.edu.vn)

Đề tài soạn: 10/2022, chỉnh sửa: 11/2022, chấp nhận đăng: 12/2022.

nguồn phát. Hay bài báo [12] cho thấy truyền gói tin ngắn qua IRS kết hợp với công nghệ NOMA có hiệu năng vượt trội hơn so với kết hợp giữa IRS và công nghệ đa truy nhập trực giao (OMA) để truyền gói tin ngắn.

Hiện nay, mặc dù nghiên cứu truyền gói tin ngắn qua IRS được các nhà nghiên cứu quan tâm, tuy nhiên số lượng bài báo vẫn còn khá hạn chế. Hầu hết, các tác giả chủ yếu tập trung phân tích sự ảnh hưởng của hiệu năng hệ thống qua tỉ số lỗi khối (BLER) vào các tham số như công suất nguồn phát, số yếu tố phản xạ và độ rộng phổ. Vấn đề tồn tại khi nghiên cứu truyền gói tin ngắn qua IRS trong các hệ thống mạng 5G và thế hệ tiếp theo là làm sao đảm bảo được cả hai yêu cầu về độ tin cậy cao và độ trễ cực thấp uRLLCs. Tức là tìm lời giải cho bài toán tối ưu hệ thống sao cho phải đảm bảo được  $BLER \leq 10^{-5}$  và độ trễ nhỏ hơn 1ms. Điều này khó có thể giải quyết bằng phương pháp số thông thường vì hàm mục tiêu cho bài toán tối ưu thường phức tạp và không lồi. Mặt khác, gần đây kỹ thuật học sâu (đặc biệt mạng nơ ron sâu) đã được công nhận là mô hình hiệu quả để giải quyết các thử thách uRLLCs trong mạng không dây thế hệ mới [17] và các hệ thống IoT [18]. Cụ thể, các tác giả trong [19] đề xuất phương pháp học sâu để dự đoán sự phân bố nguồn tài nguyên và lập lịch truy cập uRLLCs cho hệ thống truyền gói tin ngắn. Bài báo cho thấy phương pháp học sâu mang lại kết quả dự đoán chính xác và thời gian thực hiện ngắn phù hợp yêu cầu độ trễ thực của hệ thống 5G. Ở bài báo [20], các tác giả nghiên cứu kỹ thuật học sâu dự đoán BLER và thông lượng truyền gói tin ngắn trong hệ thống mạng nhận thức IoT đa truy nhập không trực giao. Bài báo chứng tỏ kết quả dự đoán từ DNN có độ chính xác cao và độ trễ thấp hơn so với các phương pháp khác, đặc biệt là mô phỏng theo Monte Carlo.

**B. Đóng góp chính của bài báo**


Dựa trên ưu điểm vượt trội của kỹ thuật học sâu và mặt phản xạ thông minh trong truyền tin gói tin ngắn nhằm đáp ứng yêu cầu cực kỳ nghiêm ngặt về độ tin cậy và độ trễ của hệ thống uRLLCs cho mạng không dây thế hệ tương lai. Đóng góp chính của chúng tôi trong bài báo được liệt kê như sau

- Đầu tiên, chúng tôi đề xuất mô hình truyền thông tin gói ngắn có sự hỗ trợ của mặt phản xạ thông minh. Từ mô hình đề xuất, tỉ số lỗi khối dạng chính xác được dẫn ra để đánh giá hiệu năng cho hệ thống.
- Thứ hai, chúng tôi đề xuất mô hình mạng nơ ron sâu DNN để ước lượng công suất phân bổ nguồn phát cho hệ thống đã đề xuất sao cho đạt yêu cầu uRLLCs.
- Cuối cùng, chúng tôi đề xuất phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE) để đánh giá kết quả dự đoán của mô hình mạng DNN. Qua đó, kết quả của bài báo cho thấy được sự cải tiến vượt trội của phương pháp học sâu dựa trên mô hình DNN về độ chính xác và thời gian thực thi hệ thống.

Về cách trình bày, bài báo được phân bổ như sau. Phần II sẽ trình bày mô hình của hệ thống mạng chuyên tiếp qua mặt IRS và đánh giá hiệu năng hệ thống qua BLER. Mô hình mạng DNN, cách tạo tập dữ liệu và phương pháp đánh giá cho mô hình mạng đề xuất được trình bày trong Phần III. Phần IV, chúng tôi minh chứng sự cải tiến của mô hình mạng đề xuất qua mô phỏng Matlab. Cuối cùng là phần kết luận của bài báo.

**II. MÔ HÌNH VÀ ĐÁNH GIÁ HIỆU NĂNG HỆ THỐNG**

**A. Mô hình**



Hình 1. Mô hình truyền gói tin ngắn qua mặt phản xạ thông minh.

Mô hình hệ thống truyền gói tin ngắn qua IRS được mô tả qua Hình 1. Hệ thống bao gồm một nguồn phát sóng (S), một nguồn nhận (D) và một IRS bao gồm N phần tử phản xạ thụ động. Giả sử rằng nguồn S và đích D sử dụng một ăng ten để truyền và nhận tín hiệu. Ở đây, chúng tôi cũng giả sử rằng không có đường truyền trực tiếp giữa nguồn và đích do vật cản từ môi trường. Hơn nữa, kênh truyền giữa nguồn và đích là kênh Rayleigh fading bán tĩnh phẳng.

Bởi vì IRS hoạt động như một bộ phản xạ thông minh, do đó IRS có thể phối hợp, trao đổi thông tin trạng thái kênh từ nguồn và đích thông qua bộ điều khiển không dây [21]. Từ đó IRS có thể điều chỉnh pha của tất cả phần tử phản xạ sao cho tỉ số tín hiệu trên nhiễu nhận tại đích đạt lớn nhất [22]. Mặt khác, do suy hao tín hiệu đáng kể nên chúng tôi bỏ qua tín hiệu phản xạ trên IRS từ hai lần trở lên và chỉ xét tín hiệu phản xạ một lần [23]. Tín hiệu nhận tại đích D được biểu diễn như sau:

$$y_D = \sqrt{P} \left[ \sum_{i=1}^N h_i r_i g_i \right] x_D + n_D, \quad (1)$$

với P là công suất phát của nguồn S, x\_D là tín hiệu cần truyền đến đích D, n\_D là nhiễu Gauss trắng cộng (AWGN) với trung bình 0 và phương sai N\_0. Hơn nữa, r\_i = e^{j\phi\_i} là hệ số phản xạ được tạo ra bởi yếu tố phản xạ thứ i trong IRS (i=1,2,...,N) [13] và \phi\_i là độ dịch chuyển pha của yếu tố phản xạ thứ i trong IRS. Kế tiếp, h\_i và g\_i là hệ số kênh truyền từ nguồn S đến yếu tố phản xạ thứ i trong IRS và từ yếu tố phản xạ thứ i đến đích D, tương ứng.

$$h_i = d_1^{-\nu/2} \alpha_i e^{-j\theta_i}, \quad (2)$$

$$g_i = d_2^{-\nu/2} \beta_i e^{-j\varphi_i}, \quad (3)$$

với \alpha\_i và \beta\_i; \theta\_i và \varphi\_i lần lượt là biên độ và độ dịch pha của hệ số kênh h\_i và g\_i; d\_1 và d\_2 lần lượt là khoảng cách từ nguồn S đến IRS và từ IRS đến đích, tương ứng; \nu là hệ số suy hao đường truyền. Chúng tôi cũng giả sử hệ thống giao tiếp được xét trong trường gần, nghĩa là khoảng cách giữa nguồn hoặc đích đến chính giữa IRS nhỏ

hơn  $\frac{2L^2}{\lambda}$ , với  $L$  kích thước cực đại của IRS và  $\lambda$  là bước sóng của tín hiệu truyền [24].

Từ (1), tỉ số tín hiệu trên nhiễu (SNR) tức thời thu được tại đích  $D$  được xác định như sau

$$\gamma_D = \frac{P \left| \sum_{i=1}^N \alpha_i \beta_i e^{j(\phi_i - \theta_i - \varphi_i)} \right|^2}{d_1^v d_2^v N_0}. \quad (4)$$

Ở đây, IRS chọn góc dịch chuyển pha  $\phi_i = \theta_i + \varphi_i$  sao cho SNR trong (4) đạt giá trị lớn nhất [24]. Do đó, (4) có thể được viết gọn lại như sau

$$\gamma_D = Z^2 \bar{\gamma}, \quad (5)$$

với  $Z = \sum_{i=1}^N \frac{\alpha_i \beta_i}{d_1^v d_2^v}$  và  $\bar{\gamma} = \frac{P}{N_0}$  là SNR trung bình.

Theo [Định lý 1, 13], từ (5) hàm mật độ xác suất (PDF) và hàm phân phối tích lũy (CDF) của  $\gamma$  có dạng như sau

$$f_\gamma(\gamma) = \frac{1}{2b^{a+1} \Gamma(a+1) \bar{\gamma}^{\frac{a+1}{2}}} \gamma^{\left(\frac{a-1}{2}\right)} \exp\left(\frac{1}{b} \sqrt{\gamma/\bar{\gamma}}\right), \quad (6)$$

và

$$F_\gamma(\gamma) = \frac{\Upsilon\left(a+1, \frac{1}{b} \sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)} \stackrel{(i)}{=} 1 - \frac{\Gamma\left(a+1, \frac{1}{b} \sqrt{\frac{\gamma}{\bar{\gamma}}}\right)}{\Gamma(a+1)}, \quad (7)$$

với (i) là phép rút gọn sử dụng [25, CT(8356.3)]; hàm gamma và gamma không hoàn chỉnh cận trên được định nghĩa theo [25, CT(8.310.1)] và [25, CT(8.350.2)] như sau

$$\Gamma(\alpha) = \int_0^\infty e^{-t} t^{\alpha-1} dt. \quad (8)$$

$$\Gamma(\alpha, x) = \int_x^\infty e^{-t} t^{\alpha-1} dt. \quad (9)$$

và các tham số

$$a = \frac{\delta_1^2}{\delta_2} - 1, \quad (10)$$

$$b = \frac{\delta_2}{\delta_1}, \quad (11)$$

$$\delta_1 = \frac{N\pi}{4} \sqrt{\frac{1}{d_1^v d_2^v}}, \quad (12)$$

$$\delta_2 = \frac{N}{d_1^v d_2^v} \left(1 - \frac{\pi^2}{16}\right). \quad (13)$$

### B. Đánh giá hiệu năng hệ thống

Trong phần này, chúng tôi sử dụng thông số tỉ lệ lỗi khối để đánh giá hiệu năng của hệ thống truyền tin gói ngắn qua IRS.

Chúng tôi giả sử hệ thống truyền ở chế độ X, truyền  $\beta$  bits thông tin qua  $k$  kênh sử dụng ( $k \geq 100$ ) với tốc độ truyền  $R_x = \frac{\beta_x}{k}$  và có tỷ lệ SNR  $\gamma_x$ .

Theo như trong [26, CT(59)] và [27, CT(4)], tỉ lệ lỗi khối trung bình BLER xấp xỉ ở chế độ X được dẫn ra như sau

$$\bar{\epsilon}_x \approx \int_0^\infty Q\left(\frac{C(\gamma_x) - R_x}{\sqrt{V(\gamma_x)/k}}\right) f_{\gamma_x}(\gamma) d\gamma, \quad (14)$$

với  $C(\gamma_x) = \log_2(1 + \gamma_x)$  là dung lượng kênh

Shannon,  $V(\gamma_x) = \left(1 - \frac{1}{(1 + \gamma_x)^2}\right) (\log_2 e)^2$  là độ phân tán

kênh truyền,  $Q^{-1}(\cdot)$  là ngược của hàm Q-function với

$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^\infty \exp\left(-\frac{t^2}{2}\right) dt$  [28],  $f_{\gamma_x}(\gamma)$  là hàm mật độ

xác suất của  $\gamma_x$ . Để đơn giản trong việc tính toán, chúng tôi sử dụng xấp xỉ của hàm  $Q(\cdot)$  theo [29, CT(14)], cụ thể như sau

$$Q\left(\frac{C(\gamma_x) - R_x}{\sqrt{V(\gamma_x)/k}}\right) \approx \Psi(\gamma_x),$$

với

$$\Psi(\gamma_x) = \begin{cases} 1, & \gamma_x \leq \rho_L, \\ 0.5 - v\sqrt{k}(\gamma_x - \theta), & \rho_L < \gamma_x < \rho_H, \\ 0, & \gamma_x \geq \rho_H, \end{cases} \quad (15)$$

với  $v = \left[2\pi(2^{2R_x} - 1)\right]^{-1/2}$ ,  $\theta = 2^{R_x} - 1$ ,

$$\rho_H = \theta + \frac{1}{2v\sqrt{k}} \text{ và } \rho_L = \theta - \frac{1}{2v\sqrt{k}}.$$

Bằng cách thay (15) vào (14) và thực hiện phép lấy tích phân từng phần, tỉ lệ lỗi khối trung bình BLER thu được như sau

$$\bar{\epsilon}_x = v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma_x}(\gamma) d\gamma. \quad (16)$$

Thay (7) vào (16), tỉ lệ lỗi khối toàn trình của hệ thống chuyên tiếp qua IRS thu được như sau

$$\begin{aligned} \bar{\varepsilon} &= v\sqrt{k} \int_{\rho_L}^{\rho_H} F_{\gamma}(\gamma) d\gamma, \\ &= v\sqrt{k} \left[ \rho_H - \rho_L - \frac{2}{\Gamma(a+1)} \left( \Delta(\sqrt{\rho_H}) - \Delta(\sqrt{\rho_L}) \right) \right], \end{aligned} \quad (17)$$

với hàm  $\Delta(\gamma)$  được đặt như sau

$$\begin{aligned} \Delta(\gamma) &= \frac{1}{2} \left[ \gamma^2 \Gamma \left( a+1, \frac{\gamma}{b\sqrt{\gamma}} \right) - \frac{\gamma^{a+2}}{\left( b\sqrt{\gamma} \right)^a} e^{-\frac{\gamma}{b\sqrt{\gamma}}} \right. \\ &\quad \left. - \frac{(a+2)}{\left( \frac{1}{b\sqrt{\gamma}} \right)^2} \Gamma \left( a+2, \frac{\gamma}{b\sqrt{\gamma}} \right) \right]. \end{aligned} \quad (18)$$

Với mục tiêu hướng đến của hệ thống là có thể đáp ứng dịch vụ uRLLCs, do đó chúng tôi quan tâm đến vấn đề tối ưu công suất phân bổ của nguồn sao cho đạt tối ưu. Bài toán tối ưu công suất được viết dưới dạng như sau

$$\min_{\mathbf{P}} \varepsilon(\mathbf{P}) \text{ s.t. } \mathbf{P} \leq P_0, \quad (19)$$

với  $P_0$  là tổng công suất phân bổ cho nguồn phát.

Từ (17), ta nhận thấy hàm mục tiêu  $\varepsilon(\mathbf{P})$  là hàm không lồi. Điều này dẫn đến bài toán tối ưu trong (19) cũng không lồi và khó có thể giải được bằng phương pháp lấy đạo hàm riêng. Để giải quyết khó khăn này, chúng tôi đề xuất kỹ thuật học sâu dựa trên cơ sở xây dựng mạng nơ ron sâu DNN được trình bày trong Phần III.

### III. MẠNG NƠ RON SÂU

Trong phần này, chúng tôi đề xuất mạng DNN để giải quyết vấn đề trong (19), tức ước lượng công suất nguồn phát  $\hat{P}$  của hệ thống dưới điều kiện ràng buộc tỉ số lỗi khối BLER  $\leq 10^{-5}$  phù hợp yêu cầu dịch vụ uRLLCs [30].


#### A. Mô hình mạng DNN

Mô hình mạng DNN gồm một lớp vào, một lớp ra và  $L-1$  lớp ẩn được trình bày qua Hình 2. Lớp vào chứa một neuron tương ứng với một nút chỉ tham số  $\varepsilon$ . Để có được tham số  $\varepsilon$  này, chúng tôi sử dụng các giá trị được liệt kê như trong **Error! Reference source not found.** để tính  $\varepsilon$  thông qua công thức (17). Ở lớp ra của mô hình chứa một neuron tương ứng với nút công suất phát của nguồn  $\hat{P}$ .

Bảng 1. Giá trị các tham số tính BLER.

Tham số	Giá trị	Tham số	Giá trị
$\bar{\gamma}$	[-10dB, 19dB]	$k$	200CUs
$N$	4	$v$	2

$d_1$	1m	$\beta$	256 bits
$d_2$	1m		



Hình 2. Mô hình mạng nơ ron sâu.

Tiếp theo, để hiểu rõ hơn về mô hình mạng DNN chúng tôi giả sử rằng mô hình chứa  $L-1$  lớp ẩn. Mỗi lớp ẩn  $l$  với  $l=1, \dots, L-1$  có chứa  $Q^{(l)}$  nơ ron và nhận hàm kích hoạt Sigmoid. Hàm kích hoạt trong mạng nơ ron được hiểu là hàm ánh xạ các đầu vào của một nút với đầu ra tương ứng [31]. Hàm Sigmoid có nhiều ưu điểm nổi trội hơn so với các hàm kích hoạt khác như tính toán đơn giản và tối ưu dễ dàng, tránh được vấn đề đạo hàm vô cùng nhỏ tại các lớp nơ ron đầu tiên trong quá trình lan truyền ngược (vanishing gradients) [32].

Đầu ra  $y^{(l)}$  của lớp thứ  $l$  của mô hình DNN được tính như sau [16, CT. (13)]

$$y^{(l)} = g^{(l)} \left( w^{(l)} y^{(l-1)} + b^{(l)} \right), \quad (20)$$

với  $g^{(l)}(x) = \frac{1}{1+e^{-x}}$  là hàm kích hoạt,  $w^{(l)}$  là trọng số và  $b^{(l)}$  ngưỡng dự kiến của của lớp thứ  $l$ . Dựa và (20), giá trị đầu ra  $\hat{P}$  có thể được tính như sau

$$\hat{P} = G(\varepsilon; \Omega), \quad (21)$$

với  $G(\cdot)$  là hàm chưa biết và học được của mạng DNN;  $\varepsilon$  là vectơ đầu vào và

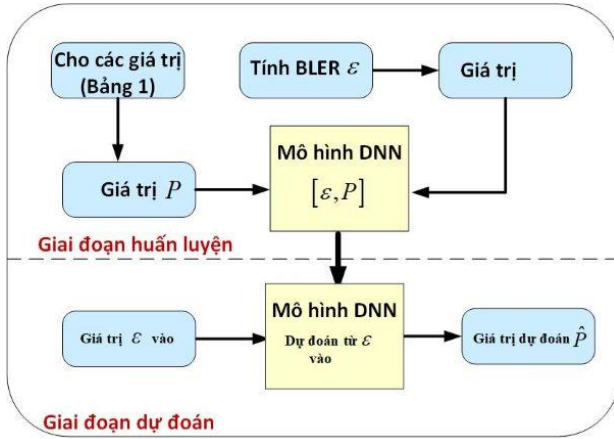
$\Omega \square \{w^{(l)}, b^{(l)}, l=1, \dots, L-1\}$  là tập hợp các tham số và trọng số của DNN.

Để tạo được mạng DNN chúng tôi tiến hành hai giai đoạn dựa vào mô hình học sâu gồm giai đoạn huấn luyện và giai đoạn dự đoán như **Hình 3**.

Trong giai đoạn huấn luyện, mạng sử dụng thuật toán tối ưu như Levenberg- Marquardt algorithm (LMA). LMA là một trong các thuật toán tối ưu phổ biến trong huấn luyện mạng nơ ron và có tốc độ hội tụ nhanh [33]. Chúng tôi chọn LMA để tối ưu các tham số của mô hình dựa vào tập dữ liệu huấn luyện trong suốt quá trình học ngoại tuyến. Đồng thời, mạng trải qua quá trình lan truyền ngược từng bước xác định hàm mất mát, độ lệch và cập nhật các trọng số.

Sau khi kết thúc quá trình huấn luyện, mạng DNN được tạo ra và có thể được sử dụng cho dự đoán trực tuyến thông qua quá trình dự đoán bất cứ khi nào có thông tin mới ở đầu vào. Vì toàn bộ giai đoạn huấn luyện diễn ra

ngoại tuyến, mạng thiết kế có thể giảm đáng kể độ phức tạp tính toán, chi phí triển khai và thời gian thực hiện [34].



Hình 3. Cấu trúc của các giai đoạn dự đoán và huấn luyện của mô hình học sâu.

### B. Tạo lập dữ liệu

Trong phần này chúng tôi trình bày cách tạo ra tập dữ liệu cho quá trình huấn luyện mạng DNN. Đầu tiên, chúng tôi sử dụng các giá trị như trong **Error! Reference source not found.** để tính giá trị BLER  $\epsilon$  dựa vào phương trình (17). Để đảm bảo yêu cầu dịch vụ uRLLCs, chúng tôi chọn BLER  $\epsilon = [10^{-7} - 10^{-5}]$  làm biến đầu vào của các mẫu huấn luyện  $j$  trong tập dữ liệu  $M$  của mạng DNN và được tạo đồng nhất dựa trên kích thước mạng. Tập dữ liệu được tạo  $M$  gồm các vectơ đặc trưng đầu vào BLER  $\epsilon^{(j)}$  và đầu ra công suất phát  $P^{(j)}$ , tương ứng. Tập dữ liệu có thể được biểu diễn như  $[\epsilon^{(j)}, P^{(j)}], j = 1, \dots, M$ . Trong mô hình của chúng tôi, tập dữ liệu được tạo ra có 2060 mẫu và được chia 70% cho tập huấn luyện, 30% còn lại chia đều cho tập đánh giá  $M_{val}$  và tập kiểm thử  $M_{tes}$ .

### C. Đánh giá RMSE

Sau khi hoàn thành quá trình huấn luyện, mô hình mạng DNN được tạo ra thông qua một hàm ánh xạ  $G(\epsilon; \Omega)$ . Từ hàm  $G$  này, quá trình dự đoán giá trị  $\hat{P}$  bắt đầu thực hiện với bất kỳ biến đầu vào  $\epsilon$ . Chú ý rằng giá trị biến  $\epsilon$  thuộc tập dữ liệu  $M$ . Để đánh giá tính hiệu quả của mô hình mạng DNN, chúng tôi sử dụng phương pháp đánh giá lỗi trung bình bình phương gốc (RMSE). Theo thống kê học, phương pháp RMSE là một trong những phương pháp hiệu quả để đo độ sai lệch giữa những giá trị dự đoán và giá trị thực tiễn [35]. Phương pháp RMSE dựa trên mô hình DNN của chúng tôi được biểu diễn qua hàm  $\Delta$  như sau

$$\Delta = \sqrt{\frac{1}{M_{tes}} \sum_{j=1}^{M_{tes}} (P^{(j)} - \hat{P}^{(j)})^2}, \quad (22)$$

với  $P^{(j)}$  và  $\hat{P}^{(j)}$  là giá trị công suất mong muốn (tức giá trị huấn luyện ban đầu) và công suất dự đoán được từ mô hình DNN.

Ta để ý rằng giá trị  $\Delta$  tỉ lệ nghịch với tập mẫu kiểm tra  $M_{tes}$  (tức sai số  $\Delta$  càng bé khi  $M_{tes}$  càng tăng). Hay nói cách khác mức độ ước lượng kết quả của mô hình DNN của chúng ta càng tin cậy khi  $\Delta$  càng nhỏ.

## IV. KẾT QUẢ MÔ PHỎNG

Trong phần này, chúng tôi trình bày các kết quả mô phỏng để cho thấy hiệu quả của mô hình mạng DNN đã đề xuất qua phần mềm mô phỏng Matlab. Giả sử mô hình truyền gói tin ngắn được xét trong không gian 2D với tọa độ của nguồn  $S$ , IRS và đích  $D$  là  $(0,0)$ ,  $(1,0)$  và  $(2,0)$  tương ứng. Tiếp theo, chúng tôi sử dụng các giá trị tham số để tính BLER như giá trị trung bình SNR  $\bar{\gamma} = [-10\text{dB}, 19\text{dB}]$ , số yếu tố phản xạ  $N = 4$ , các khoảng cách  $d_1 = d_2 = 1\text{m}$ , chiều dài gói tin  $k = 200\text{CU}$ s, số bits thông tin  $\beta = 256\text{bits}$  được liệt kê như trong **Error! Reference source not found.** Chúng tôi nhắc lại

rằng  $\bar{\gamma} = \frac{P}{N_0}$  với mật độ nhiễu  $N_0$  được chuẩn hóa bằng

1. Do vậy giá trị công suất phát  $P$  trong phần mô phỏng này được xem như cũng chính là giá trị trung bình SNR.


Các thông số cho quá trình huấn luyện mạng DNN được thiết lập gồm số neuron trên mỗi lớp chứa 100 neuron, tốc độ học  $10^{-3}$  và chu kỳ huấn luyện 1000 epochs. Đặc biệt, chúng tôi tạo được tập dữ liệu 2060 giá trị và chia theo tỉ lệ 70% cho quá trình huấn luyện, 15% cho đánh giá và 15% cho dự đoán kết quả.

Sau quá trình huấn luyện và tạo mạng DNN, chúng tôi thu được các kết quả thông qua mô phỏng minh họa trong các hình từ Hình 4 đến Hình 5.

Đầu tiên, chúng tôi trình bày sự ảnh hưởng của công suất phát  $P$  vào BLER hệ thống qua mô hình mạng DNN ở các lớp ẩn lần lượt 1, 2, 4 và 10 lớp như trong Hình 4. Quan sát hình ta thấy rõ rằng BLER càng giảm khi tăng công suất phát  $P$  ở trường hợp lý thuyết (đường liền nét) và trường hợp mô phỏng kết quả dự đoán từ DNN (các đường nét chấm). Đặc biệt, đường mô phỏng kết quả dự đoán từ DNN khớp hoàn toàn với kết quả lý thuyết ở số lớp ẩn từ 4 và 10 lớp. Ở các lớp ẩn lớn, công suất tăng thì BLER càng giảm dần. Ta biết rằng mạng DNN với nhiều lớp ẩn thì khả năng tạo được tập dữ liệu lớn dẫn tới công suất mạng sẽ cao. Còn ở mô hình mạng DNN 1 lớp không thể học các mẫu phức tạp trong một tập dữ liệu có số chiều lớn [36].


Cụ thể, kết quả dự đoán của mô hình DNN từ 2 lớp ẩn trở đi gần như trùng nhau. Tuy nhiên, ta cần phải cân nhắc việc chọn lựa số lớp ẩn vì số lớp ẩn càng lớn thì dễ gây ra hiện tượng quá khớp với dữ liệu huấn luyện (overfitting). Điều này dễ dẫn đến kết quả không chính xác trên tập kiểm tra. Hơn nữa, Hình 4 cũng cho thấy rõ hệ thống thỏa điều kiện tối ưu như trong (19) thì công suất phát phải đạt  $P \geq 12\text{ (dB)}$ .





Hình 4. Sự ảnh hưởng công suất dự đoán  $P$  so với BLER qua mô hình mạng DNN.

Tiếp theo, chúng tôi đánh giá độ tin cậy của mô hình mạng DNN thông qua chỉ số RMSE như trong Hình 5. Từ Hình 5, ta thấy rằng RMSE phụ thuộc vào số số mẫu kiểm tra  $M$  (chú ý  $M$  thuộc tập kiểm tra  $M_{tes}$ ). Cụ thể, số mẫu  $M$  càng tăng thì RMSE càng giảm. Điều này hoàn toàn phù hợp với lý thuyết theo (25). Hơn nữa, ta cũng thấy rằng giá trị RMSE ở 1 lớp cao hơn ở các lớp lớn hơn. Do đó, kết quả dự đoán từ DNN của 1 lớp sẽ kém tin cậy hơn ở các lớp cao hơn. Số lớp càng tăng thì độ tin cậy càng cao, tức RMSE càng giảm. Bởi vì khi số lớp ẩn quá nhiều thì trong quá trình huấn luyện mạng dễ xảy ra hiện tượng mất đạo hàm (vanishing gradient). Trong quá trình huấn luyện, giá trị đạo hàm là thông tin phản hồi của quá trình lan truyền ngược. Giá trị này trở nên vô cùng nhỏ tại các lớp nơ ron đầu tiên khiến cho việc cập nhật trọng số mạng không thể xảy ra.



Hình 5. Ảnh hưởng RMSE vào số mẫu kiểm tra  $M$  và số lớp ẩn.

Qua đó, ta thấy rằng để kết quả dự đoán đạt được độ tin cậy cao thì phải tăng số mẫu thử và chọn số lớp ẩn phù hợp. Tuy nhiên, việc tăng số lớp ẩn cần phải cân nhắc vì sẽ ảnh hưởng đến thời gian thực thi hệ thống thông qua

Chúng ta có thể thấy được rằng thời gian thực thi của quá trình dự đoán qua kỹ thuật học sâu dựa vào mạng DNN cực kỳ ngắn so với mô phỏng quá trình tính toán lý thuyết.

Tuy nhiên, số lớp ẩn càng lớn thì thời gian thực thi mô phỏng cũng tăng theo. Do vậy, để đảm bảo yêu cầu độ trễ của dịch vụ uRLLCs ( $\leq 1ms$ ), lớp ẩn tối ưu thực thi của hệ thống mạng truyền gói tin ngắn của chúng tôi được chọn là 4 lớp ẩn.

Bảng 2. So sánh thời gian thực thi mô phỏng lý thuyết và mạng DNN của hệ thống.

Loại	Thời gian thực hiện
Lý thuyết	1.712116 (s)
DNN- 1 lớp	0.00627 (s)
DNN- 2 lớp	0.00703(s)
DNN- 4 lớp	0.007707(s)
DNN-10 lớp	0.017568(s)

V. KẾT LUẬN

Trong bài báo này, chúng tôi đã đề xuất kỹ thuật học sâu, dựa vào mô hình DNN để dự đoán công suất tối ưu cho nguồn phát sao cho đạt uRLLCs cho hệ thống truyền gói tin ngắn qua mặt phản xạ thông minh IRS. Các kết quả bài báo cho thấy được giá trị công suất được dự đoán từ mô hình mạng DNN trùng khớp với giá trị công suất được huấn luyện ở các lớp ẩn như 2, 4 và 10 lớp. Hơn nữa, giá trị RMSE càng giảm khi số mẫu kiểm tra và số lớp ẩn tăng. Nói một cách khác, kết quả dự đoán từ DNN đạt độ tin cậy khi tăng số mẫu kiểm tra và tăng số lớp ẩn. Tuy nhiên, chúng ta cần cân nhắc khi tăng số lớp ẩn quá nhiều sẽ ảnh hưởng đến độ trễ của hệ thống do thời gian thực thi hệ thống mạng tăng và giảm độ tin cậy của hệ thống. Để đáp ứng yêu cầu uRLLCs lớp ẩn tối ưu cho hệ thống của chúng tôi được chọn là 4 lớp.

LỜI CẢM ƠN

Nghiên cứu này được hỗ trợ bởi các nghiên cứu viên tại Phòng thí nghiệm thông tin vô tuyến và được tài trợ bởi Học Viện Công nghệ Bưu Chính Viễn Thông dưới mã số 08-HV-2022-RD\_CB2.

TÀI LIỆU THAM KHẢO

[1] J. Sachs, G. Wikstrom, T. Dudda, R. Baldemair, and K. Kittichokechai, "5G radio network design for ultra-reliable low-latency communication," *IEEE Network*, vol. 32, no. 2, pp. 24-31, 2018.

[2] S. Zhang, X. Xu, Y. Wu, and L. Lu, "5G: Towards energy-efficient, low-latency and high-reliable communications networks," in *2014 IEEE international conference on communication systems*, 2014, pp. 197-201: IEEE.

[3] S. Krishna Sharma and X. Wang, "Towards Massive Machine Type Communications in Ultra-Dense Cellular IoT Networks: Current Issues and Machine Learning-Assisted Solutions," *arXiv e-prints*, p. arXiv: 1808.02924, 2018.

[4] P. Schulz *et al.*, "Latency critical IoT applications in 5G: Perspective on the design of radio interface and network

- architecture," *IEEE Communications Magazine*, vol. 55, no. 2, pp. 70-78, 2017.
- [5] G. Durisi, T. Koch, and P. Popovski, "Toward massive, ultrareliable, and low-latency wireless communication with short packets," *Proceedings of the IEEE*, vol. 104, no. 9, pp. 1711-1726, 2016.
- [6] Y. Polyanskiy, H. V. Poor, and S. Verdú, "Channel coding rate in the finite blocklength regime," *IEEE Transactions on Information Theory*, vol. 56, no. 5, p. 2307, 2010.
- [7] Y. Hu, A. Schmeink, and J. Gross, "Relaying with finite blocklength: Challenge vs. opportunity," in *2016 IEEE Sensor Array and Multichannel Signal Processing Workshop (SAM)*, 2016, pp. 1-5: IEEE.
- [8] P. Nouri, H. Alves, R. D. Souza, and M. Latva-aho, "Ultra-reliable short message cooperative relaying protocols under Nakagami-m fading," in *2017 International Symposium on Wireless Communication Systems (ISWCS)*, 2017, pp. 287-292: IEEE.
- [9] V. N. Q. Bao and T. T. Thanh, "Performance Analysis of Partial Relay Selection Networks with Short Packet Communications," *The 6th NAFOSTED Conference on Information and Computer Science (NICS)*, pp. 23-26, 2019.
- [10] N. T. Y. Linh, N. H. Tú, and V. N. Q. Bảo, "Đánh Giá Hiệu Năng Mạng Chuyên Tiếp Từng Phần Với Đa Anten Thu Trong Truyền Thông Gói Tin Ngắn," *Journal of Science and Technology on Information and Communications*, vol. 1, no. 4A, pp. 53-61, 2020.
- [11] V. N. Q. B. Nguyễn Thị Yến Linh, Phạm Ngọc Sơn, "Phân Tích Độ Lợi Phân Tập Cho Mạng Chuyên Tiếp Qua Mặt Phản Xạ Thông Minh Và Nút Chuyên Tiếp Trong Truyền Thông Gói Tin Ngắn," *Journal of Science and Technology on Information and Communications (JSTIC)*, vol. 01, no. 04B, pp. 56-64, 2021 2021.
- [12] T.-H. Vu, T.-V. Nguyen, D. B. Da Costa, and S. Kim, "Intelligent Reflecting Surface-Aided Short-Packet Non-Orthogonal Multiple Access Systems," *IEEE Transactions on Vehicular Technology*, 2022.
- [13] A.-A. A. Boulogeorgos and A. Alexiou, "Performance Analysis of Reconfigurable Intelligent Surface-Assisted Wireless Systems and Comparison With Relaying," *IEEE Access*, vol. 8, pp. 94463-94483, 2020.
- [14] L. Yang, Y. Yang, M. O. Hasna, and M.-S. Alouini, "Coverage, Probability of SNR Gain, and DOR Analysis of RIS-Aided Communication Systems," *IEEE Wireless Communications Letters*, 2020.
- [15] E. Basar, M. Di Renzo, J. De Rosny, M. Debbah, M.-S. Alouini, and R. Zhang, "Wireless communications through reconfigurable intelligent surfaces," *IEEE Access*, vol. 7, pp. 116753-116773, 2019.
- [16] C. Zhang, P. Patras, and H. Haddadi, "Deep learning in mobile and wireless networking: A survey," *IEEE Communications surveys & tutorials*, vol. 21, no. 3, pp. 2224-2287, 2019.
- [17] A. Salh *et al.*, "A Survey on Deep Learning for Ultra-Reliable and Low-Latency Communications Challenges on 6G Wireless Systems," *IEEE Access*, vol. 9, pp. 55098-55131, 2021.
- [18] Q. Mao, F. Hu, and Q. Hao, "Deep learning for intelligent wireless networks: A comprehensive survey," *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 2595-2621, 2018.
- [19] M. Y. Abdelsadek, Y. Gadallah, and M. H. Ahmed, "Resource Allocation of URLLC and eMBB Mixed Traffic in 5G Networks: A Deep Learning Approach," in *GLOBECOM 2020-2020 IEEE Global Communications Conference*, 2020, pp. 1-6: IEEE.
- [20] T.-H. Vu, T.-V. Nguyen, T.-T. Nguyen, and S. Kim, "Performance Analysis and Deep Learning Design of Wireless Powered Cognitive NOMA IoT Short-Packet Communications with Imperfect CSI and SIC," *IEEE Internet of Things Journal*, 2021.
- [21] X. Tan, Z. Sun, J. M. Jornet, and D. Pados, "Increasing indoor spectrum sharing capacity using smart reflect-array," in *2016 IEEE International Conference on Communications (ICC)*, 2016, pp. 1-6: IEEE.
- [22] Q. Wu and R. Zhang, "Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming," *IEEE Transactions on Wireless Communications*, vol. 18, no. 11, pp. 5394-5409, 2019.
- [23] Q. Wu and R. Zhang, "Towards Smart and Reconfigurable Environment: Intelligent Reflecting Surface Aided Wireless Network," *IEEE Communications Magazine*, vol. 58, no. 1, pp. 106-112, 2020.
- [24] W. Tang *et al.*, "Wireless communications with reconfigurable intelligent surface: Path loss modeling and experimental measurement," *IEEE Transactions on Wireless Communications*, 2020.
- [25] I. S. Gradshteyn and I. M. Ryzhik, *Table of integrals, series, and products*. Academic press, 2014.
- [26] W. Yang, G. Durisi, T. Koch, and Y. Polyanskiy, "Quasi-static multipleantenna fading channels at finite blocklength," *IEEE Transactions on Information Theory*, vol. 60, no. 7, p. 4232, 2014.
- [27] Yuehua Yu, He Chen, Yonghui Li, Zhiguo Ding, and Branka Vucetic, "On the Performance of Non-Orthogonal Multiple Access in Short-Packet Communications," *IEEE Communications Letters*, vol. 22, no. 3, pp. 590-593, 2018.
- [28] P. C. S. S. Freear, "Novel expressions for the Marcum and one dimensional Q-functions," *2010 7th International Symposium on Wireless Communication Systems*, 19-22 Sept. 2010.
- [29] B. Makki, T. Svensson, and Z. Michele, "Finite Block-Length Analysis of the Incremental Redundancy HARQ," *IEEE Wireless Commun. Lett.*, vol. 3, no. 5, pp. 529-532, Oct. 2014.
- [30] P. Popovski *et al.*, "Wireless access for ultra-reliable low-latency communication: Principles and building blocks," *Ieee Network*, vol. 32, no. 2, pp. 16-23, 2018.
- [31] S. Sharma, S. Sharma, and A. Athaiya, "Activation functions in neural networks," *towards data science*, vol. 6, no. 12, pp. 310-316, 2017.
- [32] D.-A. Clevert, T. Unterthiner, and S. Hochreiter, "Fast and accurate deep network learning by exponential linear units (elus)," *arXiv preprint arXiv:1511.07289*, 2015.
- [33] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [34] C. D. Ho, T.-V. Nguyen, T. Huynh-The, T.-T. Nguyen, D. B. da Costa, and B. An, "Short-packet communications in wireless-powered cognitive IoT networks: Performance analysis and deep learning evaluation," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 3, pp. 2894-2899, 2021.
- [35] W. Wang and Y. Lu, "Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model," in *IOP conference series: materials science*

and engineering, 2018, vol. 324, no. 1, p. 012049: IOP Publishing.

[36] T. O'shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, no. 4, pp. 563-575, 2017.

### DEEP LEARNING BASED THE TRANSMIT POWER PREDICTION FOR INTELLIGENT REFLECTING SURFACE-ASSISTED SHORT PACKET COMMUNICATIONS

**Abstract:** In this paper, we propose a deep neural network model to predict the transmit power of the source for intelligent reflecting surface-assisted short packet communications that meets the extremely high reliability requirements of uRLLCs. Approximated expressions of the average block error rate (BLER) are derived over Rayleigh fading channels, based on which a dataset is created for the training and testing of the DNN. For evaluating the improvement of the DNN, the root mean square error (RMSE) method is utilized. Simulation results show RMSE significantly decreases when a number of test samples increase.

**Keywords:** Deep learning, intelligent reflecting surface, Rayleigh fading, short packet communications.



**Phạm Ngọc Sơn** tốt nghiệp Tiến sĩ chuyên ngành điện tử viễn thông tại Đại học Ulsan, Hàn Quốc vào năm 2015. Hiện nay, TS. Sơn là giảng viên của Bộ Môn Kỹ Thuật Máy Tính Viễn Thông, Khoa Điện – Điện Tử, Trường Trường Đại học Sư Phạm Kỹ Thuật TP. Hồ Chí Minh (HCMUTE). Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý, thu thập năng lượng vô tuyến, đa truy cập không trực giao, mặt phản xạ thông minh và truyền thông gói tin ngắn.



**Nguyễn Thị Yến Linh** hiện đang là giảng viên thuộc Khoa Cơ Bản 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh, nhận bằng Thạc sĩ vào năm 2008 tại Trường Khoa Học Tự Nhiên TP. HCM. Hiện nay, ThS Linh đang là nghiên cứu sinh ngành kỹ thuật điện tử của Trường Đại học Sư Phạm Kỹ

Thuật TP. Hồ Chí Minh (HCMUTE). Hướng nghiên cứu chính bao gồm: truyền thông hợp tác, thu thập năng lượng vô tuyến, truyền thông gói tin ngắn và deep learning.



**Võ Nguyễn Quốc Bảo** tốt nghiệp Tiến sĩ chuyên ngành vô tuyến tại Đại học Ulsan, Hàn Quốc vào năm 2010. Hiện nay, TS. Bảo là phó giáo sư của Bộ Môn Vô Tuyến, Khoa Viễn Thông 2, Học Viện Công Nghệ Bưu Chính Viễn Thông Cơ Sở Thành Phố Hồ Chí Minh và đồng thời là giám đốc của phòng thí nghiệm nghiên cứu vô tuyến (WCOMM). TS.

Bảo hiện là thành viên chủ chốt (senior member) của IEEE và là tổng biên tập kỹ thuật của tạp chí REV Journal on Electronics and Communication. TS. Bảo đồng thời là biên tập viên (editor) của nhiều tạp chí khoa học chuyên ngành uy tín trong và ngoài nước, ví dụ: Transactions on Emerging Telecommunications Technologies (Wiley ETT), VNU Journal of Computer Science and Communication Engineering. TS. Bảo đã tham gia tổ chức nhiều hội nghị quốc gia và quốc tế, ví dụ: ATC (2013, 2014), NAFOSTED-NICS (2014, 2015, 2016), REV-ECIT 2015, ComManTel (2014, 2015) và SigComTel 2017. Hướng nghiên cứu hiện tại đang quan tâm bao gồm: vô tuyến nhận thức, truyền thông hợp tác, truyền song công, bảo mật lớp vật lý và thu thập năng lượng vô tuyến và deep learning.